

개선된 Max-Min 신경망을 이용한 콘크리트 균열 인식

김 광 백*, 박 현 정**

Recognition of Concrete Surface Cracks Using Enhanced Max-Min Neural Networks

Kwang-baek Kim*, Hyun-Jung Park**

요 약

본 논문에서는 콘크리트 표면 균열의 방향성을 효율적으로 인식하기 위하여 영상처리 기법을 적용하여 균열을 자동으로 검출하고 개선된 Max-Min 신경망을 제안하여 균열의 방향성을 자동으로 인식하는 기법을 제안한다. 균열 영상에서 빛의 영향을 효율적으로 보정하기 위해 모폴로지 기법인 채움 연산을 적용하고 Sobel 마스크를 적용하여 균열의 에지를 추출한 후, 반복 이진화를 적용하여 균열 영상을 이진화한다. 이진화된 균열 영상에서 2차례에 걸쳐 잡음 제거 연산을 수행한 후, 균열을 추출한다. 본 논문에서는 Max-Min 신경망을 개선하여 추출된 균열의 방향성을 자동으로 인식한다. 개선된 Max-Min 신경망은 delta-bar-delta 알고리즘을 적용하여 학습률을 자동으로 조정한다. 실제 콘크리트 표면 균열 영상을 대상으로 실험한 결과, 개선된 Max-Min 신경망이 균열의 방향성 인식에 효율적임을 확인하였다.

Abstract

In this paper, we proposed the image processing techniques for extracting the cracks in a concrete surface crack image and the enhanced Max-Min neural network for recognizing the directions of the extracted cracks. The image processing techniques used are the closing operation of morphological techniques, the Sobel masking for extracting for edges of the cracks, and the iterated binarization for acquiring the binarized image from the crack image. The cracks are extracted from the concrete surface image after applying two times of noise reduction to the binarized image. We proposed the method for automatically recognizing the directions of the cracks with the enhanced Max-Min neural network. Also, we propose an enhanced Max-Min neural network by auto-tuning of learning rate using delta-bar-delta algorithm. The experiments using real concrete crack images showed that the cracks in the concrete crack images were effectively extracted and the enhanced Max-Min neural network was effective in the recognition of direction of the extracted cracks.

▶ Keyword : Enhanced Max-Min neural network, Concrete surface crack, Morphological techniques, Delta-bar-delta

• 제1저자 : 김광백 · 교신저자 : 박현정
• 접수일 : 2007.4.13, 심사일 : 2007.4.18, 심사완료일 : 2007. 5.20.
* 신라대학교 컴퓨터공학과 부교수 **신라대학교 건축학부 조교수

1. 서론

콘크리트 구조물에 발생한 균열은 구조물의 내력, 내구성, 방수성 및 미관 등에 악영향을 미치기 때문에 균열은 콘크리트 구조물을 건설할 때 가장 중요한 문제이다. 그러므로 균열 발생 시 균열의 원인을 정확히 조사하여 구조물의 내구성 및 안정성에 대한 평가를 해야 하며, 필요한 경우에는 보수·보강 대책을 수립하여야 한다. 따라서 콘크리트 구조물에 발생한 균열원인을 추정할 때 균열의 패턴이나 분포 특성은 그 발생 원인을 판단하는데 중요한 인자이다 [1]. 대부분 균열이 발생하면 점검자의 수작업에 의해 계속되어 점검자의 주관이 개입될 수 있기 때문에 컴퓨터를 통해 객관적으로 계속할 수 있는 기법을 필요로 한다[2][3].

따라서 본 논문에서는 디지털 카메라로 획득된 균열 영상에서 자동으로 균열을 검출하고 Max-Min 신경망을 개선하여 균열의 방향성(-45°방향, 45°방향, 횡방향, 종방향)을 자동으로 인식하는 기법을 제안한다. 본 논문에서는 빛의 영향을 효율적으로 보정하기 위하여 모폴로지 기법인 채움(Closing) 연산을 수행하고 소벨 마스크를 이용하여 균열의 에지를 검출한 후, 반복 이진화[4]를 적용하여 영상을 이진화 한다. 이진화된 영상에서 3×3 마스크를 이용하여 인접화소의 평균을 구하여 미세한 잡음을 제거하고, Glassfire Labeling 알고리즘을 이용하여 가로 및 세로의 일정한 비율을 분석하여 잡음을 제거한 후, 균열의 특정 부분을 검출한다. 검출된 균열 영상에서 개선된 Max-Min 신경망을 적용하여 균열의 특정 부분의 방향성(-45°방향, 45°방향, 횡방향, 종방향)을 자동으로 인식한다. 개선된 Max-Min 신경망은 delta-bar-delta 기법을 적용하여 학습률을 자동으로 조정하는 기법이다.

II. 영상 처리 기법을 이용한 균열 검출

본 논문에서의 균열 검출 및 균열 인식 알고리즘의 개요도는 그림 1과 같다. 먼저 균열 영상에서 빛의 영향을 제거하고 소벨 마스크를 이용하여 에지를 검출한 후, 반복 이진화를 적용하여 균열 영상을 이진화 한다. 이진화된 균열 영상에서 두 차례에 걸쳐 잡음 제거 연산을 수행한 후, 특정 부분의 균열을 검출한다. 추출된 특정 부분의 균열을 개선된 Max-Min 신경망을 적용하여 균열의 방향성(-45°방향, 45°방향, 횡방향, 종방향)을 인식한다.

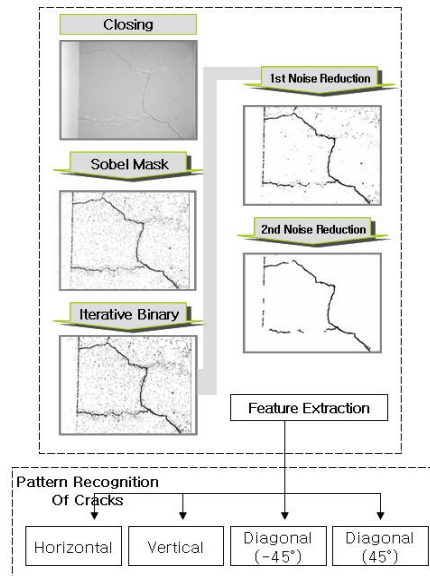


그림 1. 균열 검출 및 인식 알고리즘의 개요도
Fig. 1. Overview of proposed crack detection and recognition algorithm

2.1 빛의 영향 보정

디지털 카메라로 획득한 영상은 환경적인 요소로 인하여 빛의 방향과 양에 따라 배경의 밝기가 달라진다. 이러한 빛의 영향 때문에 밝기 값에 민감하게 반응하는 소벨 마스크를 적용하여 균열의 에지를 추출할 경우에는 어두운 부분에서는 에지를 추출할 수 없게 된다. 따라서, 빛의 영향을 효과적으로 보정하기 위하여 모폴로지 기법 중의 하나인 채움(Closing) 연산을 적용한다. 그림 2는 채움(Closing) 연산의 과정을 나타낸다.




그림 2. 채움(Closing) 연산의 과정
Fig. 2. Process of closing operator

2.2 균열의 에지 추출

에지 검출은 미분 연산자에 의한 밝기 값의 변화를 이용하여 찾아내는 것이며 직접적인 계산보다는 마스크 형태를 이용하여 빠른 계산을 하는 것이 더욱 효과적이다. 따라서 콘크리트 표면의 균열과 표면간의 급격한 밝기 차를 이용하여 그림 3과 같은 두 개의 소벨 마스크를 Closing된 영상

에 적용하여 균열의 에지를 추출한다.

| | | |
|----|---|---|
| -1 | 0 | 1 |
| -2 | 0 | 2 |
| -1 | 0 | 1 |

Sobel-X

| | | |
|----|----|----|
| -1 | -2 | -1 |
| 0 | 0 | 0 |
| 1 | 2 | 1 |

Sobel-Y

그림 3. Sobel 마스크
Fig. 3. Sobel Mask

| | | |
|---|---|---|
| 0 | 0 | 0 |
| 0 | 0 | 1 |
| 0 | 1 | 0 |

| | | |
|---|---|---|
| 1 | 1 | 1 |
| 1 | 1 | 1 |
| 1 | 0 | 0 |

그림 5. 잡음 제거를 위한 3x3 마스크
Fig. 5. 3x3 Mask for Noise Reduction

2.3 균열 영상의 이진화

반복 이진화 방법은 임계값을 설정한 뒤, 그림 4의 알고리즘을 이용하여 임계값의 변동이 없을 때까지 반복한 후, 최종 임계값을 설정한다[5]. 반복 이진화 알고리즘은 그림 4와 같다.

Step 1. 임계값의 처음 추정치 T^t 를 선정한다.

Step 2. 추정 임계값 T^t 를 이용하여 영상을 2개의 영역 R_1 과 R_2 로 구분한다.

Step 3. 각 영역의 평균 그레이 값 u_1 과 u_2 를 구한다.

$$u_1 = \frac{\sum f(i,j)}{N_1} \quad u_2 = \frac{\sum f(i,j)}{N_2}$$

여기서 N_1 과 N_2 은 각 영역의 화소 개수이다.

Step 4. 새로운 임계값을 다음 식을 이용하여 결정한다.

$$T^{(t+1)} = \frac{u_1 + u_2}{2}$$

Step 5. u_1 과 u_2 가 더 이상 변하지 않을 때까지 단계 2에서 단계 4의 과정을 반복한다.

그림 4. 반복 이진화 알고리즘
Fig. 4. Repetitive binarization algorithm

2.4 잡음제거

균열 이외의 잡음을 제거하기 위하여 2회에 걸쳐 잡음 제거 연산을 수행한다. 먼저 이진화된 영상에 3x3 마스크를 이용하여 왼쪽부터 오른쪽으로 위에서 아래 방향으로 진행하면서 인접화소 9개의 화소값들 중에 그림 5에서와 같이 1을 가진 화소들이 더 많으면 중심 화소의 값을 1로 설정하고 0을 가진 화소들이 더 많으면 0으로 설정하여 미세한 잡음을 먼저 제거한다.

1차적으로 잡음이 제거된 영상에서 나머지 잡음을 제거하기 위해 Glassfire Labeling 기법을 적용하여 2차적으로 잡음을 제거한다. Glassfire Labeling은 자기호출을 이용하여 모든 인접화소가 Labeling될 때까지 현재 관심 화소의 주변 인접화소를 차례로 검사하면서 Labeling하는 방법이다. 따라서 Labeling된 영상에서 참고문헌 [6]과 같이 각각의 라벨영역의 첫 번째 화소와 마지막 화소를 이용하여 각 영역의 면적을 구한다. 본 논문에서는 실험을 통하여 면적의 기준 값을 1.7로 설정하여 가로 및 세로 비율이 1.7이하가 되면 잡음으로 간주하여 제거하였다.

III. 개선된 Max-Min 신경망을 이용한 균열 인식

3.1 패턴 인자 추출

영상 처리 기법을 이용하여 검출한 균열 영상에서 균열의 방향성을 인식하기 위해 특정 부분의 균열을 추출하여 입력패턴으로 적용한다. 검출된 균열 영상에서 Glassfire Labeling기법을 적용하여 같은 Label을 가진 영역의 첫 번째 화소와 마지막 화소를 이용하여 전체 영상에서 특정 부분의 균열을 자동 추출한다. 이렇게 추출된 특정 부분의 균열은 그 크기가 모두 다르기 때문에 입력 패턴으로 적용하기에는 부적당하다. 따라서, 본 논문에서는 추출된 특정 부분의 균열을 입력 패턴으로 사용하기 위해서 추출된 특정 부분의 균열 크기를 30x30 픽셀로 확대하거나 축소시켜 입력 패턴으로 적용한다.

3.2 개선된 Max-Min 신경망

Max-Min 신경망은 퍼지의 기본 연산자를 사용하고 0과 1사이의 값을 입력 패턴으로 적용하여 학습하는 알고리즘이다. 이 알고리즘의 장점은 기존의 단층 알고리즘이 이진 데

이터를 학습하는데 중점을 둔 반면에 퍼지 값인 0과 1사이의 값을 학습하는데 효과적으로 학습할 수 있도록 퍼지 논리 연산자를 이용한 것이 큰 장점이다. 그러나 이 알고리즘은 실제 적용에 있어 패턴의 수가 많아지는 경우에는 수렴성이 떨어지는 단점 있고 n bit parity 문제와 같이 비선형 문제에 대해서는 학습의 수렴성이 낮아지는 경우가 발생한다. Max-Min 신경망의 알고리즘은 다음과 같다[7].

단계 1. 입력값 $V_k = (v_{k1}, \dots, v_{km})$ 과 목표값

$T_k = (t_{k1}, \dots, t_{kn})$ 을 제시한다.

단계 2. $O_k = (o_{k1}, \dots, o_{kn})$ 은 출력값을 나타내고 r_{ij} 은 가중치로서 임의의 값으로 초기화한다. θ_i 은 바이어스 항으로서 임의의 값으로 초기값을 설정한다. w_{ki} 은 이 학습 알고리즘의 실제적인 초기 가중치를 계산하는 값으로 계산하는 식은 다음과 같다.

$$w_{ki} = \sqrt{\bigwedge \{v_{ki}, r_{1i}\}, \dots, \bigwedge \{v_{km}, r_{mi}\}}$$

여기서, \bigvee 은 퍼지 논리 합 연산자이고 \bigwedge 은 퍼지 논리 곱 연산자이다.

$$o_{ki} = w_{ki} \bigvee \theta_i$$

단계 3. 목표 값과 출력값 사이의 오류 값을 계산한다.

여기서 Q는 Total Sum of Square이다.

$$Q = \frac{1}{2} \sum_{k=1}^K \sum_{i=1}^n (o_{ki} - t_{ki})^2$$

단계 4. 가중치와 바이어스항을 조정한다.

$$r_{ij}(l+1) = r_{ij}(l) + \eta_1 \Delta r_{ij}(l+1) + \alpha_1 \Delta r_{ij}(l),$$

$$\theta_i(l+1) = \theta_i(l) + \eta_2 \Delta \theta_i(l+1) + \alpha_2 \Delta \theta_i(l),$$

$$\Delta r_{ij} = 1, \text{ when } o_{ki} = r_{ij}$$

$$= 0, \text{ otherwise.}$$

$$\Delta \theta_i = 1, \text{ if } o_{ki} = \theta_i$$

$$= 0, \text{ otherwise.}$$

단계 5. 오류 한계 값을 만족할 때까지 단계 2로 가서 반복한다.

본 논문에서는 Max-Min 신경망에서 delta-bar-delta 방법[8]을 적용하여 학습률을 동적으로 조정한 개선된 Max-Min 신경망을 제안하여 균열 인식에 적용한다.

delta-bar-delta 규칙은 각 출력 뉴런에 대하여 현재의 정보를 식 (1)과 같이 delta-bar를 형성하기 위하여 파생된 과거의 정보를 조합하여 이용한다.

$$\overline{\Delta}_{kj}(t) = (1 - \beta) \Delta_{kj}(t) + \beta \overline{\Delta}_{kj}(t-1) \dots \dots \dots (1)$$

식(1)에서 파라미터 β 의 값은 $0 < \beta < 1$ 사이의 고정된 상수이다. 본 논문에서 Max-Min 신경망에서 delta와 delta-bar 변화에 대한 학습률의 변화는 다음과 같다. 만약 연결강도의 변화가 연속된 학습과정에서 같은 방향으로 이루어진다면 학습률은 증가한다. 이것은 $\overline{\Delta}_{ki}(t-1)$ 과 $\Delta_{ki}(t)$ 가 같은 부호에서 발생하며, 이 때 학습률을 증가시킨다. 또한 만약 $\overline{\Delta}_{ki}(t-1)$ 과 $\Delta_{ki}(t)$ 의 부호가 반대 부호를 가지면 학습률은 현재값의 $(1 - \gamma)$ 의 비율로 감소한다. 이러한 가변 학습률은 다음과 같은 식으로 표현된다.

$$a_{ki}(t+1) = a_{ki}(t) + k \quad \text{if } \overline{\Delta}_{ki}(t-1) \cdot \Delta_{ki}(t) > 0$$

$$= (1 - \gamma) a_{ki}(t) \quad \text{if } \overline{\Delta}_{ki}(t-1) \cdot \Delta_{ki}(t) < 0$$

$$= a_{ki}(t) \quad \text{if } \overline{\Delta}_{ki}(t-1) \cdot \Delta_{ki}(t) = 0$$

..... (2)

IV. 실험 및 결과 분석

실험 환경은 Intel Pentium-IV 2GHz CPU와 256MB RAM이 장착된 IBM 호환 PC상에서 VC++ 6.0으로 구현하였고 실험에 적용된 균열 영상은 Sony사의 Cyber-Shot 5.0 디지털 카메라로 획득된 영상을 대상으로 성능 평가 실험에 적용하였다. 획득된 콘크리트 균열 영상에서 특정 부분의 균열을 자동 검출하고 제안된 Max-Min 신경망의 입력패턴으로 사용하여 균열의 방향성을 인식하였다. 그림 6은 균열 영상에서 특정 부분의 균열을 추출한 결과이고, 그림 7은 추출된 특정 부분 균열의 방향성을 인식한 결과이다.

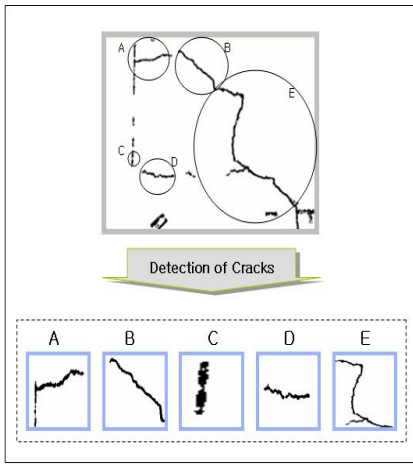


그림 6. 특정 부분의 균열 추출 결과
Fig. 6. Specific crack extraction in a crack image

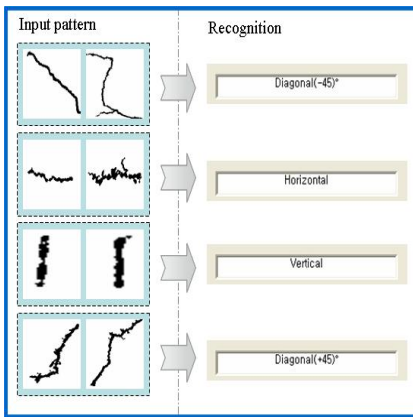


그림 7. 특정 부분 균열의 방향성 인식 결과
Fig. 7. Directional recognition result of specific crack

Max-Min 신경망과 개선된 Max-Min 신경망의 학습 및 인식 성능을 분석하기 위해 입력 패턴으로는 추출된 25 개의 균열 패턴을 사용하였고, 출력층의 노드 수는 5개, 초기 학습률은 0.8, 모멘텀은 0.5로 설정하였다. 그리고 개선된 Max-Min 신경망에서 delta-bar 상수인 κ, γ, β 는 각각 0.05, 0.2, 0.75로 설정하였다. 표 1은 기존의 Max-Min 신경망과 개선된 Max-Min 신경망 간의 학습 및 인식 결과를 나타내었다.

표 1. 특정 균열의 방향성 학습 및 인식 결과
Table 1. Directional training and recognition result of specific crack

| | Max-Min 신경망 | 제안된 Max-Min 신경망 |
|---------|-------------|-----------------|
| Epoch 수 | 219 | 113 |
| 인식률 | 23 / 25 | 24 / 25 |
| TSS | 0.49701 | 0.00001 |

표 1에서 균열 인식에 실패한 경우는 균열 영상에서 미세하게 작은 특정 부분의 균열 영역을 확대하여 입력 패턴으로 사용한 경우이다. 이는 전처리 과정에서 일부 균열의 특징이 잠음으로 분류되어 제거되었기 때문이다. 표 1에서 기존의 Max-Min 신경망보다 제안된 Max-Min 신경망이 학습 시간이 적게 소요되는 것을 확인할 수 있다. 따라서, 균열의 방향성 인식을 위해 패턴들이 증가할 경우에는 기존의 Max-Min 신경망은 지역 최소화에 위치할 가능성이 높으나 제안된 Max-Min 신경망은 학습률을 동적으로 조정하기 때문에 기존의 Max-Min 신경망 보다 학습의 수렴성과 인식률이 개선되는 것을 표 1에서 확인할 수 있다. 그림 8은 두 알고리즘 간의 Epoch수에 따른 TSS 변화량을 나타내었다.

그림 8에서와 같이 개선된 Max-Min 신경망은 학습률을 동적으로 조정하기 때문에 기존의 Max-Min 신경망 보다 학습의 수렴성이 빠른 것을 확인 할 수 있다.




그림 8. Epoch 수와 TSS 변화
Fig. 8. Epoch number and TSS variation

V. 결론

디지털 카메라로 콘크리트 표면의 균열 영상을 획득하여 균열을 검출하고 Max-Min 신경망을 개선하여 균열의 방향성(-45°방향, 45°방향, 횡방향, 종방향)을 인식하는 방법을 제안하였다. 콘크리트 표면 균열 영상을 모폴로지 기법의 채움 연산을 적용하여 빛의 영향을 보정하고 소벨 마

스크를 이용하여 균열의 에지를 추출한 후, 반복 이진화를 적용하여 영상을 이진화하였다. 이진화된 균열 영상에서 3×3 마스크를 이용하여 1차적으로 미세한 잡음을 제거한 후, 나머지 잡음을 Glassfire Labeling 기법을 적용하여 Labeling된 부분의 비율이 1.7 이하이면 잡음으로 간주하여 제거하였다. 두 차례에 걸쳐 잡음이 제거된 영상에서 특정부분의 균열을 추출하고 추출된 특정 부분의 균열을 30×30 크기로 확대하거나 축소하여 개선된 Max-Min 신경망의 입력 패턴으로 설정하여 균열의 방향성(-45°방향, 45°방향, 횡방향, 종방향)을 인식하였다. 균열의 특정 부분을 개선된 Max-Min 신경망에 적용한 결과, 균열의 방향성(-45°방향, 45°방향, 횡방향, 종방향) 인식에 효율적인 것을 확인하였다.

참고문헌

- [1] 한국콘크리트학회, 최신콘크리트공학, 기문당, 1992.
- [2] 이방연, 박연동, 김진근, " 콘크리트 표면 균열 패턴 인식 기법 개발," 한국콘크리트학회 논문집, 17권, 3호, pp.369-374, 2005.
- [3] Y. S. Kim, C. T. Haas, "An Algorithm for Automatic Crack Detection, Mapping and Representation," KSCE Journal of Civil Engineering, Vol.4, No.2, pp.103-111, 2000.
- [4] R. C. Gonzalez, R. E. Woods, S. L. Eddins, Digital Image Processing, Pearson Prentice Hall, 2004.
- [5] 김광백, 김영주, "퍼지 소속 함수를 이용한 개선된 이진화 방법," 한국컴퓨터정보학회논문지, 10권 1호, pp.67-72, 2005.
- [6] 김광백, 조재현, 안상호, "콘크리트 표면의 영상 처리 기법," 한국해양정보통신학회논문지, 9권 7호, pp.1575-1582, 2005.
- [7] L. S. Hsu, et als., "Fuzzy Neural-Logic System", Proceedings of IJCNN, Vol.1, pp.254-250, 1992.
- [8] K. B. Kim, A. S. Oh, A. Pandya, " Fuzzy Neural Network with Enhanced Learning Algorithm", Journal of Electronics and Computer Science, Vol.6, No.1, pp.9-14, 2004.

저자 소개



김 광 백

1999년 부산대학교 전자계산학과 (이학박사)

1997년~현재 신라대학교 컴퓨터공학과 부교수

2005년~현재 한국해양정보통신학회 이사 및 논문지 편집부 위원장

〈관심분야〉 Fuzzy Neural Networks, Image Processing, SVM, Bioinformatics



박 현 정

2001년 부산대학교 일반대학원 건축공학과 (공학박사)

2003년~현재 신라대학교 건축학부 조교수

〈관심분야〉 Fuzzy Neural Networks, Image Processing